


Algoritmos genéticos

Frederico Gadelha Guimarães

frederico.g.guimaraes@gmail.com



Algoritmos genéticos



Algoritmos genéticos

- ▶ Algoritmos genéticos são algoritmos heurísticos que trabalham com uma população de **representações abstratas (genótipo)** de soluções candidatas para problemas de busca e otimização;
- ▶ A população evolui por meio de operadores heurísticos de seleção e reprodução;
- ▶ Algoritmos genéticos representam uma classe particular de algoritmo evolutivos;



Algoritmos genéticos

- ▶ Questões de projeto:
- ▶ Representação (genótipo – fenótipo);
- ▶ Operadores de seleção;
- ▶ Operadores de reprodução;




Algoritmos genéticos

- ▶ Terminologia / analogias:
- ▶ Gene – código para o parâmetro ou variável de otimização;
- ▶ Cromossomo – representação abstrata de uma solução candidata (genótipo);
- ▶ Indivíduo – solução candidata (fenótipo);
- ▶ População – conjunto de soluções candidatas;
- ▶ Geração – iteração, sequência de populações;
- ▶ Aptidão – medida de qualidade atribuída a um indivíduo da população;



Algoritmos genéticos

- ▶ O genótipo e o fenótipo: evolução como um processo de otimização




Algoritmos genéticos

- ▶ Introdução: Simple Genetic Algorithm (SGA) ou GA canônico (J. Holland)

Representação	Bit strings
Recombinação	1-point crossover
Mutação	Bit flip
Seleção p/ reprodução	Proporcional à aptidão
Seleção p/ sobrevivência	Geracional

Algoritmos genéticos



Algoritmos genéticos

- ▶ Introdução: Simple Genetic Algorithm (SGA) ou GA canônico (J. Holland)

String	População inicial	Valor (fenótipo)	Aptidão $f(x)$	Prob. de seleção	Cópias esperadas	Cópias
1	0 1 1 0 1	13	169	0.14	0.58	1
2	1 1 0 0 0	24	576	0.49	1.97	2
3	0 1 0 0 0	8	64	0.06	0.22	0
4	1 0 0 1 1	19	361	0.31	1.23	1

$$\max f(x), f(x) = x^2, x \in [0,31]$$



Algoritmos genéticos

- ▶ Introdução: Simple Genetic Algorithm (SGA) ou GA canônico (J. Holland)

String	População selecionada	Ponto de corte	Após cruzamento	Após mutação	Valor (fenótipo)	Aptidão $f(x)$
1	0 1 1 0 1	4	0 1 1 0 0	1 1 1 0 0	28	784
2	1 1 0 0 0	4	1 1 0 0 1	1 1 0 0 1	25	625
3	1 1 0 0 0	2	1 1 0 1 1	1 1 0 1 1	27	729
4	1 0 0 1 1	2	1 0 0 0 0	1 0 1 0 0	20	400

$$\max f(x), f(x) = x^2, x \in [0,31]$$



Algoritmos genéticos

- ▶ Porque funciona?
- ▶ Porque esse processo aparentemente arbitrário produz alguma coisa útil?
- ▶ Porque algoritmos genéticos são uma forma eficiente de otimização?



Teoria dos schemata

- ▶ **Teoria dos Schemata** (singular: schema)
- ▶ Um schema é o conjunto de todos os cromossomos com alelos idênticos em loci específicos;
- ▶ Os loci não especificados são representados por um símbolo de *don't care*;
- ▶ Template: seja o schema $H1 = \#10\#$. Esse schema representa as strings: 0100, 0101, 1100, 1101;
- ▶ Uma dada string que pertence ao schema H é denominado **exemplo** de H ;
- ▶ Em uma codificação com L bits, há 3^L schemata;



Teoria dos schemata

- ▶ A ordem $o(H)$ de um schema indica o número de posições (bits) fixadas;
- ▶ Ex.: seja $H1 = \#1\#0\#$, $o(H1)=2$; seja $H2 = \#0111$, $o(H2)=4$;

- ▶ O comprimento determinante (defining length) $d(H)$ de um schema é a distância entre a primeira e última posições fixas;
- ▶ Ex.: $d(H1)=2$ e $d(H2)=3$;




Teoria dos schemata

- ▶ A aptidão de um schema H em uma dada população $P(t)$ é dada pela média dos valores de aptidão dos indivíduos na população que são exemplos do schema H :

$$f(H) = \frac{1}{m(H, P(t))} \sum_{i: c_i \in P(t) \cap H} f(c_i)$$

Teoria dos schemata

- ▶ O espaço de busca como um hipercubo:



Teoria dos schemata


- ▶ Todo o espaço de busca pode ser dividido em $3^L - 1$ hiperplanos (ou partições), todas as combinações possíveis de 0, 1 e #;
- ▶ Cada cromossomo (genótipo) na população é um vértice do hipercubo e membro de 2^{L-1} hiperplanos;
- ▶ Um único indivíduo não fornece muita informação sobre o espaço de busca, mas uma **população** fornece muita informação sobre vários hiperplanos!
- ▶ Paralelismo implícito ou intrínseco => muitos hiperplanos são amostrados quando uma população de strings é avaliada. Fitzpatrick & Grefenstette mostraram que um algoritmo genético com N indivíduos processa na ordem de N^3 hiperplanos simultaneamente.

Teoria dos schemata


- ▶ Muitos hiperplanos são avaliados cada vez que uma string é avaliada, porém os efeitos acumulativos de se avaliar uma população de pontos é que fornece informação estatística sobre algum subconjunto particular de hiperplanos;
- ▶ Através do processo de seleção, cruzamento e mutação, os schemata de hiperplanos distintos apresentam mais ou menos representantes na população dependendo da aptidão das strings nesses hiperplanos;
- ▶ A amostragem de partições não é muito afetada por ótimos locais;




Teoria dos schemata



Teoria dos schemata



Teoria dos schemata



Teoria dos schemata


- ▶ As operações do algoritmo genético favorecem partições com aptidão acima da média – esse procedimento não garante convergência global (pico isolado) mas “boas” soluções, isto é, soluções globalmente competitivas podem ser encontradas;

- ▶ Veremos convergência global com cadeias de Markov.



Teoria dos schemata

- ▶ 1-point crossover:



Teoria dos schemata

- ▶ A ação do algoritmo genético sobre os schemata pode ser quantificada analiticamente – vamos fazer isso para o SGA;
- ▶ Seja c um exemplo de um schema H e um membro de $P(t)$. A probabilidade de seleção de c é dada por:

$$p_s(c) = \frac{f(c)}{\sum_{i=1}^N f(c_i)}$$

Teoria dos schemata

- ▶ Portanto o número de exemplos do schema H na população após a seleção é dada em média por:

$$m(H, P'_t) = N \times \sum_{i:c_i \in H \cap P_t} p_s(c_i) = N \frac{\sum_{i:c_i \in H \cap P_t} f(c_i)}{\sum_{k=1}^N f(c_k)}$$

$$m(H, P'_t) = \frac{N}{\sum_{k=1}^N f(c_k)} \times \frac{\sum_{i:c_i \in H \cap P_t} f(c_i)}{m(H, P_t)} \times m(H, P_t)$$

$$m(H, P'_t) = \frac{f(H)}{\bar{f}} m(H, P_t)$$

Teoria dos schemata

- ▶ Vamos assumir, de modo conservador, que todo cruzamento que ocorrer entre a primeira e última posição fixa de H gera um cromossomo que não pertence a H;
- ▶ Além disso, vamos assumir que nenhum cruzamento produz novos exemplos de H;
- ▶ A probabilidade de se perder exemplos de H por causa do cruzamento é dada por:

$$\frac{d(H)}{L-1} p_c$$

Após a seleção: $m(H, P'_t) = \frac{f(H)}{\bar{f}} m(H, P_t)$

Após o cruzamento: $m(H, P''_t) \geq \frac{f(H)}{\bar{f}} m(H, P_t) \left[1 - \frac{d(H)}{L-1} p_c \right]$

Teoria dos schemata

- ▶ Novamente, vamos assumir, de modo conservador, que novos exemplos de H não são criados por mutação;
- ▶ A probabilidade de se perder exemplos de H por causa da mutação é dada pela probabilidade de modificar uma de suas posições fixas:

$$(1 - p_m)^{o(H)} \approx 1 - p_m o(H)$$

Próxima geração:

$$m(H, P_{t+1}) \geq m(H, P_t) \frac{f(H)}{\bar{f}} \left[1 - p_c \frac{d(H)}{L-1} - p_m o(H) \right]$$

- ▶ **Teorema fundamental dos algoritmos genéticos**

Teoria dos schemata

$$m(H, P_{t+1}) \geq m(H, P_t) \frac{f(H)}{\bar{f}} \left[1 - p_c \frac{d(H)}{L-1} - p_m o(H) \right]$$

▶ Interpretações:

- ▶ Na ausência de cruzamento e mutação, o número de exemplos de schemata com cromossomos acima da média da população cresce exponencialmente;
- ▶ Como a definição de $f(H)$ não inclui todos os exemplos de H mas somente aqueles presentes na população o teorema não implica que os melhores schemata possíveis terão mais representantes nas próximas gerações (convergência global não garantida);



Teoria dos schemata

$$m(H, P_{t+1}) \geq m(H, P_t) \frac{f(H)}{\bar{f}} \left[1 - p_c \frac{d(H)}{L-1} - p_m o(H) \right]$$

▶ Interpretações:

- ▶ Schemata acima da média com baixa ordem e pequeno comprimento determinante recebem número cada vez maior de representantes nas gerações seguintes – *building blocks*;
- ▶ Hipótese dos blocos de construção: GAs operam selecionando schemata curtos de baixa ordem que competem entre si, os blocos de construção. As operações de reprodução combinam blocos de construção para criar schemata mais longos e de ordem mais elevada;

Teoria dos schemata


$$m(H, P_{t+1}) \geq m(H, P_t) \frac{f(H)}{\bar{f}} \left[1 - p_c \frac{d(H)}{L-1} - p_m o(H) \right]$$

▶ **Implicações:**

- ▶ *Deceptive functions*: quando o GA não funciona bem;
- ▶ Se um schema em uma partição que contém o ótimo global possui uma aptidão média inferior a um outro schema em uma partição que contém um ótimo local, o processo evolutivo tende ao ótimo local;

Teoria dos schemata

- ▶ Deceptive function (maximização):



Teoria dos schemata

- ▶ Experimento com uma função deceptiva de segunda ordem, 18 bits:
- ▶ SGA executado 200 vezes por 150 gerações com $N=1000$, $p_c=0.8$;
- ▶ 100 execuções com $p_m=0.005$, 100 execuções com $p_m=0.1$;
- ▶ Percentual de convergência para o ótimo global: **14% para $p_m=0.005$ e 29% para $p_m=0.1$** ;
- ▶ Total de avaliações: 150,000 avaliações em um espaço de busca com 262,144 soluções candidatas!

Teoria dos schemata

- ▶ Experimento com uma função deceptiva de segunda ordem, 18 bits:
- ▶ Discussão:
- ▶ Alta taxa de mutação aumenta a busca aleatória cega do algoritmo;
- ▶ Alta taxa de mutação destrói os blocos construtores, reduzindo a tendência forte para o ótimo local;




Teoria dos schemata

- ▶ Felizmente:
- ▶ Apesar da importância teórica e experimental, deceptive functions são raramente encontradas na prática;
- ▶ Um ótimo global com características deceptive não é muito interessante na prática: pouca robustez;
- ▶ Problemas práticos possuem tendências globais que podem ser exploradas eficientemente pelo algoritmo genético e seu processamento paralelo de schemata!



Trabalho computacional

- ▶ Maximização da função sinc de duas variáveis (código binário, gray);



Algoritmos genéticos

- ▶ Questões de projeto:
- ▶ Representação (genótipo – fenótipo);
- ▶ Operadores de seleção;
- ▶ Operadores de reprodução;




Representação

- ▶ As operações dos algoritmos evolutivos atuam na representação (genótipo) das soluções candidatas da população;
- ▶ Como vimos, na terminologia dos AGs faz-se um paralelo com a terminologia usada na Biologia:
- ▶ Gene – código para o parâmetro ou variável de otimização;
- ▶ Cromossomo – representação abstrata de uma solução candidata (genótipo);
- ▶ Indivíduo – solução candidata (fenótipo);
- ▶ População – conjunto de soluções candidatas;
- ▶ Geração – iteração, sequência de populações;
- ▶ Aptidão – medida de qualidade atribuída a um indivíduo da população;




Representação



- ▶ As operações dos algoritmos evolutivos atuam na representação (genótipo) das soluções candidatas da população;
- ▶ Representação binária:
 - Indicado em problemas de decisão (problema da mochila);
 - Pode representar variáveis inteiras e reais;
 - Codificação Gray;
 - Teoria do schemata;


$$[1 \ 3 \ 2 \ 6 \ 4 \ 5] \Rightarrow [001 \ 011 \ 010 \ 110 \ 100 \ 101]$$

Representação




- Representação binária – codificação:

$$x_k \in [a_k, b_k] \Rightarrow \varepsilon_k = \frac{b_k - a_k}{2^L - 1}$$




Representação




- Representação binária – decodificação:

$$x_{t,i,k} = a_k + \varepsilon_k \sum_{r=1}^{L_k} c_{t,i}[kr] 2^{L_k-r}$$




Representação



- ▶ Representação binária – codificação Gray:
- ▶ Garante que inteiros consecutivos tenham distância de Hamming igual a 1.
 - Ex.: Na codificação tradicional, 0111 (7) e 1000 (8) possuem distância Hamming igual a 3;
- ▶ Útil em problemas em que os inteiros representam quantidades ordenáveis;
- ▶ Preserva o princípio da localidade nos espaços genotípico e fenotípico;

Representação




► Representação inteira:

- Indicado em problemas de otimização inteira;
- Problema da mochila generalizado;
- Atributos ordinais (quantitativos) e cardinais (simbólicos, rótulos arbitrários);

$$\{N, S, E, W\} = \{1, 2, 3, 4\}$$


Representação




► Representação por permutações:

- Indicado em problemas de otimização inteira, em que deve-se otimizar uma sequência de eventos;
- Problema do caixeiro viajante, problema de alocação de tarefas;
- Os operadores de reprodução devem garantir a permutação;

[1 3 2 6 5 4]




Representação



- ▶ Representação por permutações:
- ▶ Problemas baseados em adjacência (TSP, ciclos);
- ▶ Problemas baseados em ordem (sequenciamento de tarefas);


$$[1 \ 3 \ 2 \ 6 \ 5 \ 4] = [4 \ 1 \ 3 \ 2 \ 6 \ 5]??$$

Representação




► Representação real:

- Indicada em problemas de otimização com variáveis reais (polêmica);
- Alfabeto de cardinalidade elevada, limitada pela representação em ponto flutuante;




Representação



▶ Outras representações:


- Matrizes binárias 2D e 3D;
- Tabelas;
- Árvores;
- Representações híbridas: binário-real; binário-permutação, etc;

Recombinação




- ▶ O papel da reprodução é gerar novas soluções candidatas a partir da informação contida nos indivíduos pais;
- ▶ A recombinação é uma operação que gera soluções em caminhos que conectam duas soluções distintas no espaço de busca;

Recombinação




- ▶ Cruzamento com um ponto de corte:




Recombinação


- ▶ Cruzamento com um ponto de corte:




Recombinação




- ▶ Cruzamento com N pontos de corte e polarização posicional:




Recombinação



- ▶ Efeito de busca ortogonal



Recombinação



- ▶ No cruzamento uniforme, cada alelo é herdado do pai 1 com probabilidade p , e herdado do pai 2 com probabilidade $(1-p)$

(0.60 0.07 0.92 0.83 0.07 0.88 0.91 0.53)

$\mathbf{x}_{t,1}$

0011	1010	0111	0001
------	------	------	------


$\mathbf{x}_{t,2}$

0011	1010	0111	0001
------	------	------	------

$x_{t,i,1}$

$x_{t,i,2}$

Recombinação




- ▶ Recombinação para representação real:
 - Discreta – extensão da recombinação de cadeias binárias;
 - Aritmética – média, intermediária, convexa;


$$u_{t,i,j} = \lambda x_{t,1,j} + (1 - \lambda) x_{t,2,j}$$

$$\lambda = U_{[0,1]}$$


Recombinação




▶ Recombinação discreta




Recombinação




▶ Recombinação aritmética




Recombinação




- ▶ A recombinação discreta não produz novos valores e causa passos ortogonais;




Recombinação




- ▶ A recombinação discreta não produz novos valores e causa passos ortogonais;




Recombinação




- ▶ A recombinação convexa pode gerar novos valores e produzir modificações em todas as coordenadas;




Recombinação



- ▶ Recombinação aritmética:
- ▶ Vantagem: capaz de gerar novos valores na faixa de variação dos alelos dos pais;
- ▶ Desvantagem: redução da faixa de variação dos alelos mesmo na ausência de pressão seletiva – contração do volume ocupado pelos indivíduos;



Recombinação




- ▶ Recombinação de permutações:
- ▶ PMX – Partially Mapped Crossover

$\mathbf{x}_{t,i}$	1	2	3	4	5	6	7	8	9
$\mathbf{x}_{t,j}$	9	3	7	8	2	6	5	1	4


9	3	7	4	5	6	7	1	4
---	---	---	---	---	---	---	---	---

Solução inválida


Recombinação




- ▶ Recombinação de permutações:
- ▶ PMX – Partially Mapped Crossover




Recombinação




- ▶ Recombinação de permutações:
- ▶ PMX – Partially Mapped Crossover




Recombinação



- ▶ Recombinação de permutações:
- ▶ PMX – Partially Mapped Crossover



Recombinação




▶ Recombinação de permutações:

▶ OX – Order Crossover


$\mathbf{x}_{t,i}$	1	2	3	4	5	6	7	8	9
$\mathbf{x}_{t,j}$	9	3	7	8	2	6	5	1	4

			4	5	6	7		
--	--	--	---	---	---	---	--	--


Recombinação



- ▶ Recombinação de permutações:
- ▶ OX – Order Crossover




Recombinação




▶ Recombinação de permutações:

▶ OX – Order Crossover




Recombinação




▶ Recombinação de permutações:

▶ OX – Order Crossover




Recombinação




▶ Recombinação de permutações:

▶ OX – Order Crossover




Recombinação




▶ Recombinação de permutações:

▶ OX – Order Crossover




Recombinação




- ▶ Recombinação de permutações:
- ▶ PMX – Partially Mapped Crossover:
 - herda um segmento de um pai, e tenta preservar o máximo de posições fixas do outro pai, evitando repetições;
 - Arestas comuns aos dois pais podem não estar presentes nos filhos;
- ▶ OX – Order Crossover:
 - Herda um segmento de um pai, e preserva a ordem relativa do segundo pai, evitando repetições;
 - Arestas comuns aos dois pais podem não estar presentes nos filhos;
- ▶ Outros operadores: variantes do PMX, Edge Crossover, Cycle Crossover, etc...

Recombinação



- ▶ Recombinação com múltiplos “pais”:
- ▶ Baseado em frequência de alelos;
- ▶ Baseado em segmentação e recombinação de fragmentos de mais de 2 pais;
- ▶ Baseado em operações sobre alelos com valores reais (centro de massa, no politopo dos pais, etc);

Mutação




- ▶ Representação binária:
 - Mutação por inversão de bits;
 - Taxa de mutação por bit e por indivíduo;
- ▶ Representação real:
 - Perturbação aleatória – Gaussiana, Cauchy, Caótica;

$$\mathbf{u}_{t,i} \leftarrow \mathbf{u}_{t,i} + \nu$$


$$\mathbf{u}_{t,i} \leftarrow \mathbf{u}_{t,i} + N(\mathbf{C}, \mathbf{0})$$

Mutação




- ▶ Representação por permutações:
 - Troca (Swap);
 - Inserção;
 - Inversão (2-opt, k-opt);
 - Scramble;

Seleção



- ▶ Seleção para reprodução:
 - Seleção proporcional à aptidão;
 - Decimação;
 - Sieriação;
 - Torneio;

Seleção





- ▶ Seleção proporcional ao valor de aptidão
- ▶ Probabilidades de seleção determinadas de acordo com os valores de aptidão:


$$\rho_{t,i} = \frac{\phi(\mathbf{x}_{t,i})}{\sum_{k=1}^N \phi(\mathbf{x}_{t,k})}$$

- ▶ Problemas:
 - Superindivíduos;
 - Perda de pressão seletiva – flutuação – em regiões em que a função varia pouco ou próximo à solução ótima;
 - Sensibilidade aos valores da função de aptidão;

Seleção




Seleção



- ▶ Solução parcial: escalonar os valores de aptidão de acordo com a média da população;
- ▶ Goldberg (1989) propôs o escalonamento sigma:

$$\varphi'(x) = \max[\varphi(x) - (\bar{\varphi} - c\sigma), 0]$$

Seleção




► Implementação computacional da seleção proporcional à aptidão

```
Para cada indivíduo  $i$  faça:  
    calcule probabilidade de seleção  $p[i]$ ;  
Fimpara
```

```
Para cada  $i$  faça:  
     $u \leftarrow U(0,1)$ ;  
     $j \leftarrow 1$ ;  
     $S \leftarrow 0$ ;  
    Enquanto  $S < u$  faça:  
         $S \leftarrow S + p[j]$ ;  $j \leftarrow j+1$ ;  
    fimenquanto  
    Selecione indivíduo  $j$  de  $P(t)$ ;  
Fimpara
```

Seleção




- ▶ Decimação

- ▶ Forma de seleção simples e determinística;
 - Somente os melhores indivíduos são selecionados;
 - Usado na seleção para sobrevivência em estratégias evolutivas;


- ▶ Problemas:
 - Perda de diversidade;
 - Boas características (bons genes) podem ser perdidos – nos estágios iniciais, bons genes podem estar presentes em indivíduos ruins;
 - Forte pressão seletiva;

Seleção



- ▶ Seriação
- ▶ Na seleção proporcional à aptidão, a seleção é fortemente dependente dos valores da função de aptidão;
- ▶ Pode-se determinar as probabilidades de seleção de acordo com a ordenação dos indivíduos;


Seleção



- ▶ Sieriação
- ▶ Controle sobre a pressão seletiva

$$\rho_{t,i} = \frac{[r_i]^\alpha}{\sum_{k=1}^N [r_k]^\alpha}$$

$$[1, N] \rightarrow [1, 0]$$



Seleção



- ▶ Seleção por torneio

- ▶ Forma de seleção estocástica bastante popular, inspirada em torneios para acasalamento:
 - Selecione T indivíduos com probabilidade uniforme;
 - Competição entre os T indivíduos, o mais apto vence;
 - Empates decididos aleatoriamente;

- ▶ Controle sobre a pressão seletiva:
 - $T=1$: seleção uniforme;
 - $T=N$: seleção determinística;

Substituição

- ▶ Geracional
 - Método mais comum em algoritmos genéticos;
- ▶ Substituição do pior
 - Cada novo indivíduo substitui o pior indivíduo da população corrente;
 - Foco no melhor indivíduo;
- ▶ Estacionário
- ▶ Elitismo
 - O melhor indivíduo é sempre reinserido na população;
 - Essencial?